

논문 2024-19-22

# 복도 환경에서 로봇 위치추정의 랭크 결핍 문제 해결을 위한 적응적 샘플링 기반 파티클 필터링 기법

## (Adaptive Sampling-Based Particle Filtering for Solving the Rank Deficiency Problem of Robot Localization in Corridor Environments)

강수현, 권유진, 이현철\*  
(Suhyeon Kang, Yujin Kwon, Heoncheol Lee)

**Abstract** : This research addresses the problem of robot localization in corridor environments using LiDAR (Light Detection and Ranging). Due to the rank deficiency problem in scan matching with LiDAR alone, the accuracy of robot localization may degenerate seriously. This paper proposes an adaptive sampling-based particle filtering method using depth sensors to overcome the rank deficiency problem. The increase in the sample size in particle filters can be considered to solve the problem. But, it may cause much computation cost. In the proposed method, the sample size of the particle set in the proposed method is adjusted adaptively to the confidence of depth sensor data. The performance of the proposed method was test by real experiments in various environments. The experimental results showed that the proposed method was capable of reducing the estimation errors and more accurate than the conventional method.

**Keywords** : Robot localization, Particle filter, Rank deficiency, Corridor environments

### 1. 서론

로봇 자율주행을 위해서는 로봇 위치추정이 필수적이다. 자율주행 로봇이 환경 내에서 안전하게 이동하고, 장애물을 피하며, 목적지에 정확하게 도달하기 위해서는 자신의 위치를 정확하게 파악하는 것이 중요하며 이는 자율주행에 필요한 가장 기본 역량 중 하나이다. 위치추정이 없다면 로봇은 주변 환경을 인식하고, 그에 맞는 의사결정을 내리는 데 필요한 중요한 정보를 잃게 되므로, 효과적인 경로 계획과 장애물 회피, 목표 지점으로의 주행이 어려워질 것이다. 따라서 로봇 위치추정은 로봇 시스템의 신뢰성과 효율성을 결정짓는 중요한 역할을 수행한다.

대부분의 로봇 위치추정 시나리오에서는 환경 지도를 사용할 수 있으며 로봇에는 환경을 관찰하고 이동을 감지하는 센서가 장착되어 있다. 그중 가장 많이 사용하는 센서는 LiDAR (Light Detection And Ranging) 센서이다 [1]. 라이다 센서를 이용한 실내 위치추정 관련 연구들은 실내의 다양한 환경을 대상으로 하는데 그중 복도 환경은 라이다 위치추정을 하는 데 있어서 하나의 도전과제라고 할 수 있

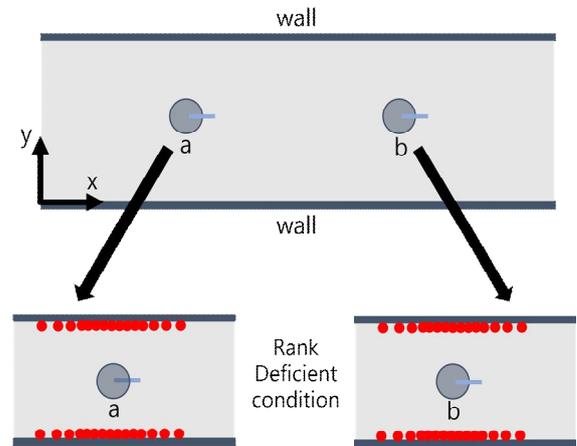


그림 1. 특징이 부족한 복도에서의 스캔 매칭 랭크 결핍 문제  
Fig. 1. The Problem of Rank Deficiency in Feature-Sparse Corridor

다 [2]. 이에 많은 연구자들이 복도 환경에서의 위치추정에 대한 연구를 진행하였다 [3-10]. 그러나 여전히 복도 환경에서의 LiDAR만을 이용한 로봇 위치추정에는 한계가 있다.

일반적으로 복도의 구조는 직선적이고 평면적인 벽과 천장이 있으며, 벽면의 요소들은 LiDAR로 유의미한 데이터를 얻을 수 있을 정도로 충분한 요소가 되지 못한다. 이는 곧 스캔 매칭의 Rank Deficiency 문제로 이어지며, 이는 로봇이 자신의 위치를 정확하게 추정하는 데에 제약을 초래한다. 일례로 그림 1과 같은 특징이 부족한 복도에서 로봇이 a와 b 중 한곳에 위치하는데, 스캔 매칭의 Rank Deficiency로 인해 어느 곳에 위치하는지 정확하게 추정할 수 없는 것

\*Corresponding Author (hcleee@kumoh.ac.kr)

Received: Jun. 18, 2024, Revised: Jul. 16, 2024, Accepted: Aug. 13, 2024.  
S. Kang: Department of IT Convergence Engineering, Kumoh National Institute of Technology (M.S. Student)

Y. Kwon: School of Electronic Engineering, Kumoh National Institute of Technology (B.S. Student)

H. Lee: Department of IT Convergence Engineering, Kumoh National Institute of Technology (Associate Professor)

※ 이 연구는 정부 (과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역저능화혁신인재양성사업 (IITP-2024-RS-2020-II2016 12) 및 산업통상부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구임 (20210630, 극한지계발 및 탐사용 협동이동체 시스템 기술개발)

표 1. 확률적 필터 기반 로봇 위치추정 관련 연구

Table 1. Related Works to Probabilistic Filter-Based Robot Localization

Related works	Rank Deficiency Problem	Estimation methods	Sensors
[11]	X	Kalman Filter	UWB
[12]	X	RBPF	LiDAR
[13]	X	PF	Depth Camera
[18], [19]	X	PF	RGB Camera
[20]	X	Kalman Filter	LiDAR
[21]	X	Kalman Filter	LiDAR and Depth Camera
Proposed	O	Adaptive Sampling-based PF	LiDAR and Depth Camera

을 들 수 있다. 다시 말해 그림 1과 같은 상황에서는 스캔 데이터가  $y$ 축 방향으로만 존재하여  $y$ 축 방향으로의 매칭이 잘 이루어지나  $x$ 축 방향으로의 매칭이 잘 이루어지지 않는 것을 의미한다. 이를 극복하기 위해서는 추가적인 센서나 알고리즘을 채택하여 복도와 같이 구조적으로 단순한 환경에서의 정확성을 강화할 필요가 있다.

실시간 로봇 시스템에서 객체 인식 및 위치추정을 수행하기 위해서 일반적으로 깊이 카메라를 이용한다. 그러나 깊이 카메라는 오차를 포함하고 있으며 센서의 측정 범위와 각도 등에 따라 센서 데이터의 오차 범위 또한 달라질 수 있다. 기존 연구들에서는 이러한 오차를 해결하기 위해 확률적 필터를 제시하기도 한다 [11-19]. 확률적 필터 기반 로봇 위치추정 관련 연구는 표 1과 같이 정리된다. 추가로 위치추정 정확도를 향상하는 방법은 다양한 방법이 있는데 알고리즘 개선을 통한 방법 [12], 환경 정보를 활용하는 방법 [18, 19] 그리고 센서 융합을 통한 방법 [21, 22] 등이 있다.

본 논문에서는 좁은 복도 환경에서 더 정확한 위치추정을 위해 깊이 카메라를 도입하였고, 깊이 카메라의 센서 노이즈 등을 제거하고 로봇 위치추정의 정확도를 향상시킬 수 있는 적응적 샘플링 기반 파티클 필터링 기법을 제안한다. 제안된 기법은 좁은 복도 환경뿐만 아니라 유리가 있는 환경, 난간이 있는 환경에서도 위치추정 성능을 개선할 수 있다. 또한 제안된 기법은 성능을 검증하기 위해 다양한 환경에서 실험이 수행되었으며, 로봇 위치추정 결과의 오차 평균 및 표준편차를 감소시킴으로써 기존 방법 대비 성능이 향상되었음이 검증되었다.

본 논문은 다음과 같은 순서로 구성되어 있다. 2장에서 복도 환경에서 LiDAR 기반 로봇 위치추정의 문제점과 Depth 센서 기반 객체 위치추정의 문제점에 대해 서술하고, 3장에서는 연구를 수행한 전체 시스템에 관하여 설명한다. 4장에서는 실험 환경 구성에 대해 서술하고 실험 결과를 분석한다. 마지막으로 5장에서 본 연구의 결론과 함께 향후 연구 방향을 제시한다.

## II. 문제점 기술

### 1. 복도 환경에서 LiDAR 기반 로봇 위치추정의 문제점

LiDAR 센서 기반 로봇 위치추정은 특징이 많은 환경에서는 잘 작동하나, 복도와 같이 변화가 적고 특징이 덜 뚜렷한 환경에서는 한계를 보이는 경향이 있다. 복도는 일반적으로 좁은 공간이며 대체로 긴 직선 구조로 되어 있고, 평평한 벽과 천장으로 이루어져 있다. 또한 벽면의 특징이 반복적이어서 LiDAR가 구별할 만한 유의미한 특징 정보가 적다. 이로 인해 복도 환경에서는 LiDAR 센서를 기반으로 로봇이 정확한 위치를 파악하는 데 어려움을 겪을 수 있다. 따라서 복도와 같이 특징이 적은 환경에서는 다른 센서의 데이터를 함께 사용하거나, 알고리즘을 추가로 적용하여 위치추정의 정확도를 향상할 필요가 있다.

### 2. Depth 센서 기반 객체 위치추정의 문제점

Depth 센서 기반 객체 위치추정을 할 때에는 조명의 변화, 객체 표면의 반사성, 투명 또는 반투명한 객체에 의해 신뢰성이 저하될 수 있다. 복잡한 배경으로 인한 대상 객체를 제대로 인식하지 못하는 경우가 있을 수 있고, 센서의 해상도와 범위 한계로 인해 먼 거리의 객체나 매우 작은 객체는 정확히 추정하기 어렵다. 또한 다양한 환경 조건에서의 견고성 부족과 데이터의 노이즈, 왜곡, 센서의 시야각 제한 등으로 인해 위치추정에 오차가 발생할 수 있다. 이러한 문제를 해결하기 위해 알고리즘 개선, 센서 융합 기법, 센서 데이터의 정밀 분석이 필요할 수 있다. 추가적으로 환경적 요인이나 객체의 물리적 특성을 더 정밀하게 분석하고, 이를 기반으로 센서의 데이터 처리 알고리즘을 조정할 수 있다. 따라서 센서 사양서를 기반으로 한 센서 데이터의 신뢰도를 측정하는 등의 기법을 포함한 알고리즘이 센서 데이터로 얻어낸 위치추정과 같은 결과에 대한 정확도를 높이는 데 중요한 역할을 할 수 있다.

## III. 제안하는 기법

### 1. 제안하는 기법을 포함한 로봇 위치추정 시스템 전체 구조

제안하는 기법의 전체적인 구조는 그림 2과 같이 심층학습 기반 객체 인식과 Depth 데이터를 기반으로 객체와 로봇 사이의 관계를 정의하여 로봇의 위치를 추정한다. 안정적인 로봇 위치추정을 위해서는 파티클 필터가 사용된다.

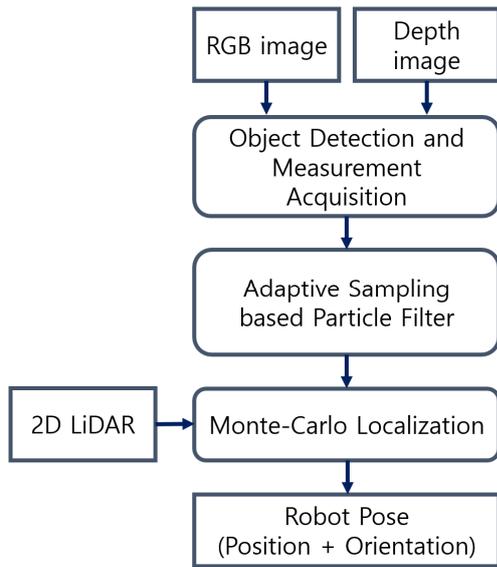


그림. 2. 로봇 위치추정 시스템 전체 구조  
Fig. 2. Overall structure diagram of Robot Localization

파티클 필터는 샘플링, 측정 업데이트, 가중치 계산, 리샘플링 단계로 진행된다. 먼저 입자들의 샘플링을 통해 초기 입자들을 생성한다. 이때 파티클의 개수는 카메라 센서의 사양에 따른 로봇 자세 예측의 불확실성을 정의하여 조절한다. 이후 측정값을 업데이트하여 예측된 입자들과 측정값 사이의 거리를 구한다. 이렇게 구해진 거리를 통해 가중치를 할당하게 된다. 이때, 가중치는 가우시안 분포에 의해 할당되며 예측된 입자들과 측정값 사이의 거리가 작을수록 더 높은 가중치를 부여한다. 부여된 가중치를 기반으로 리샘플링을 진행하게 되는데 이때 SIR (Sequential Importance Resampling) 기법이 사용되었다. SIR 기법은 주로 상태 추정 문제에 사용된다. 초기화, Prediction, 파티클 업데이트, 리샘플링의 단계로 수행되며, 단계를 반복하면서 현재 상태를 추정한다. 이후 적응적 샘플링 기반으로 파티클 개수를 상황에 따라 적응적으로 사용하여 최종적으로 위치와 각도가 포함된 로봇의 Pose를 도출한다.

2. 파티클 필터 기반 로봇 위치추정

파티클 필터는 복잡한 동적 시스템의 상태를 추정하기 위해 사용되는 베이저안 필터링 기법 중 하나이다. 이 기법을 이용한 로봇 위치추정은 로봇의 위치를 시스템의 가능한 상태를 대표하는 파티클로 나타내는 것이다. 파티클 필터 기반으로 로봇 위치추정을 하는 방법은 다음과 같다.

MCL은 로봇이 센서 관측을 바탕으로 파티클을 사용하여 상태를 추정하는 기법이다. 각 파티클은 로봇의 잠재적 상태를 나타내며, 로봇이 움직이고 새로운 센서 데이터를 받을 때마다 이 상태의 정확성에 대한 가능성을 바탕으로 파티클들이 업데이트된다. 이 파티클 집합은 시간이 지남에 따라 로봇의 가장 가능성 높은 위치로 수렴하게 되는데 예

기치 않은 센서 오류나 환경 변화로 인한 큰 추정 오류에서 신속하게 회복하는 데 한계가 있다.

EMCL (MCL with Expansion Resetting) [23]은 기존 MCL 방법의 한계를 극복하고자 제안된 기법이다. 기존의 방법은 추정된 위치 주변에 집중되어 있어 실제 로봇 위치와 크게 벗어난 경우에는 적절히 대응하지 못하는 문제가 있었다. EMCL은 이를 해결하기 위해 파티클 분포를 일시적으로 확장시켜 오류 발생 시 실제 위치 근처에 재배치될 수 있도록 하는 확장 Resetting 기법을 제안한 위치추정 방법이다.

EMCL2 (MCL with Expansion resetting 2)는 EMCL의 향상된 패키지 버전이다. EMCL과 비교하여 Reset 조건에 있어서 조금 더 세밀화되었다는 점에 있어서 EMCL2는 EMCL보다 향상된 위치추정 결과를 도출함을 알 수 있다. 따라서 본 논문에서 제안한 방법의 우수성을 검증하기 위해, 제안한 방법을 EMCL2와 정확도 측면에서 비교하였다.

3. 객체 기반 관측 모델

본 논문에서는 스캔 매칭의 Rank Deficiency가 발생하는 지점에서 위치추정 오차가 발생하는 것을 확인하였다. 이에 객체 인식을 기반으로 파티클 필터링을 거쳐 로봇의 위치를 추정하는 적응적 샘플링 기반 파티클 필터링을 제안한다. 적응적 사전 샘플링 기반 파티클 필터의 관측 모델 (Observation Model)은 객체 인식을 기반으로 로봇의 위치를 추정하는 것이다. 심층학습 모델을 통해 객체를 인식하여 얻은 Pixel 값 및 Depth 값을 통해 환경에 존재하는 객체와 로봇 간의 관계를 도출하여 로봇의 위치를 추정하게 된다.

객체 인식 및 추정 알고리즘은 현재 다양한 분야에서 연구되고 있다 [24, 25]. 본 논문의 심층학습 기반 객체 인식 단계에서는 YOLO (You Only Look Once) 심층학습 모델을 사용하였다. YOLO는 객체 인식을 위한 딥러닝 모델로, 이미지 전체를 한 번에 분석하여 객체의 위치와 분류를 동시에 수행한다. 이는 처리 속도가 빨라 실시간 시스템에 적합한 심층학습 모델이다. 이 심층학습 모델을 사용하여 로봇에 장착된 RGB-D 카메라로부터 얻은 이미지를 입력으로 받아 환경에 존재하는 객체를 인식한다. 복도 환경에서 쉽게 접할 수 있는 객체로는 비상구 표시등과 소화기가 존재한다. 따라서 본 연구에서는 복도 환경에서 쉽게 접할 수 있는 이 두 가지 객체를 학습하여 Custom 데이터셋을 제작하였다. Custom 데이터셋을 학습하는 데에는 총 1008장의 이미지가 사용되었다.

$$\begin{bmatrix} x_{GR} \\ y_{GR} \end{bmatrix} = \begin{bmatrix} x_{GO} \\ y_{GO} \end{bmatrix} - \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} x_{RO} \\ y_{RO} \end{bmatrix}. \tag{1}$$

환경에 존재하는 객체를 인식하여 로봇의 위치를 추정하는 방법은 다음과 같다. RGB-D 카메라로부터 RGB 이미지를 입력으로 받아 심층학습 모델을 통해 객체를 인식하여 바운딩 박스를 얻는다. 그리고 바운딩 박스의 중심점에서 픽셀 좌표를 카메라 좌표계의 x, y 좌표로 변환하고 그 중심점에서 얻어온 Depth 이미지를 카메라 좌표계의 z 값으로



그림 3. 심층학습 기반 객체 인식 및 객체 위치추정  
Fig. 3. Deep learning-based object recognition and Localization

변환한다. 이를 통해 그림 3과 같이 카메라 좌표계에서의 객체의 좌표를 얻는다. 그림 3에서의 좌표 표기는 순서대로 z, x, y 값을 나타낸다. 카메라 좌표계에서의 물체 위치와 글로벌 좌표계에서의 물체 위치를 통해 최종적으로 글로벌 좌표계에서의 로봇 위치를 추정하게 되는데 이때 카메라 좌표계와 글로벌 좌표계 사이의 관계를 나타내는 수식은 (1)과 같다. 이때  $x_{GR}$   $y_{GR}$  과  $x_{GO}$   $y_{GO}$  ,  $x_{RO}$   $y_{RO}$ 는 각각 ROS (robot operating system) Global 좌표계에서 로봇의 x, y 좌표, ROS Global 좌표계에서 물체의 x, y 좌표, Camera Local 좌표계에서 물체의 x, y 좌표를 나타내고,  $\theta$ 는 로봇의 yaw 값을 나타낸다. ROS는 로봇 애플리케이션 개발을 위한 오픈 소스 Framework이다. 로봇 시스템 개발에 많이 사용되며, Topic 송수신, 좌표 변환, 센서 데이터 처리 등 다양한 기능을 제공한다. ROS Global 좌표계는 일반적으로 고정되어 있으며, 로봇과 주변 환경의 상대적인 위치를 표현하는 데에 사용된다.

4. 적응적 샘플링 기반 파티클 필터링

적응적 샘플링 기반 파티클 필터링의 전반적인 구조는 그림 4와 같다. 적응적 샘플링 기반 파티클 필터링 기법은 로봇 위치의 불확실성에 따라 파티클의 수를 조절하는 기법이다. 로봇 위치의 불확실성을 정의하기 위해서는 불확실성을 결정하는 요소들을 먼저 정의해야 한다. 불확실성을 결정하는 요소들은 Edge Factor와 Distance Factor로 정의하였다. 즉, 카메라 센서 데이터의 오차에 기반하여 함수를 설계하였으며 그에 따른 요소가 정의된 것이다.

카메라로 화면을 스트리밍할 때 화면상 객체의 위치에 따라 변동되는 오차가 발생함을 실험적으로 확인하였다. 이는 표 2와 같이 객체가 이미지 평면의 가장자리 (Edge)에서 인식될수록 중심보다 깊이 값의 더 높은 오차율을 나타내었다. 이때 표 2에서 Distance는 카메라로부터 객체까지의 실제 거리를 나타낸다. 따라서 Edge Factor를 이미지 프레임의 중심으로 갈수록 1에 가까운 신뢰도를 부여하는 함수로 설계하여 정의하였다. 이는 수식 (2)~(6)과 그림 5. (a)와

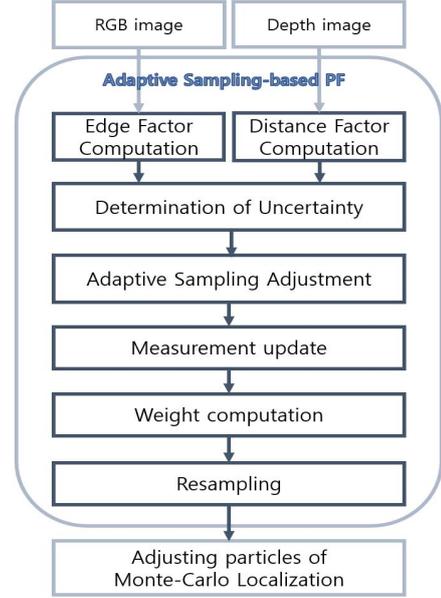


그림 4. 적응적 샘플링 기반 파티클 필터링 기법의 구조

Fig. 4. Overall structure diagram of Adaptive Sampling-based Particle Filtering

표 2. 이미지 평면에서 객체 위치에 따른 깊이 값 오차  
Table 2. Depth Value Errors Depending on Object Position in Image Plane

MSE(m) distance(m)	Center	Edge
0.5	0.001	0.009
1.0	0.004	0.014
1.5	0.004	0.059
2.0	0.023	0.081
2.5	0.015	0.037
3.0	0.011	0.256

같다. 수식에서 카메라 스트리밍 화면의 가로 및 세로는  $x_s$ ,  $y_s$ 로 표현하였고, 마운딩 박스의 중심의 픽셀 좌표는 각각  $x_p$ ,  $y_p$ 로 표현하였으며, 화면의 가장자리로부터의 마운딩 박스 중심까지의 최단 거리는 각각  $x_e$ ,  $y_e$ 로 표현하였다.  $p_x$ ,  $p_y$ 는 각각 가장자리로부터 마운딩 박스의 중심까지의 거리를 비율로 나타낸 것이다. 이때 비율은 신뢰도를 카메라 스트리밍 화면의 중심으로 갈수록 1에 가깝게 부여하므로 스트리밍 픽셀 좌표 가로, 세로 길이의 절반을 기준으로 한 비율이다. 최종적으로  $p_x$ ,  $p_y$  중 최솟값을 Edge Factor로 선정한다.

$$x_e = \min(x_p, x_s - x_p), \tag{2}$$

$$y_e = \min(y_p, y_s - y_p), \tag{3}$$

$$p_x = 2x_e / x_s, \tag{4}$$

$$p_y = 2y_e / y_s, \tag{5}$$

$$Edge\ Factor = \min(p_x, p_y). \tag{6}$$

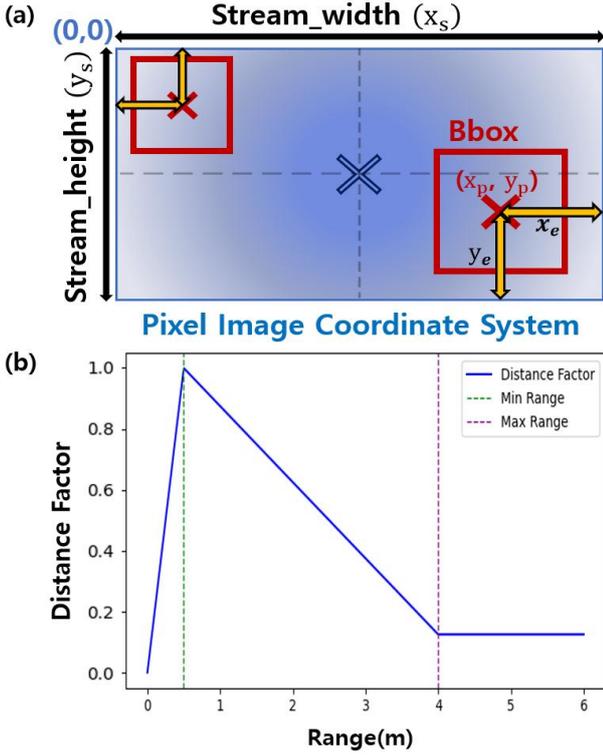


그림. 5. (a) Edge Factor 도출 방법  
(b) Distance Factor 도출 방법

Fig. 5. (a) Method of Deriving the Edge Factor  
(b) Method of Deriving the Distance Factor

Distance Factor는 카메라로부터 객체까지의 거리 즉, 깊이 값 ( $depth$ )을 측정할 때 거리에 따라 변동되는 오차를 함수로 설계하였다. 이때 카메라 사양서 및 실험에 따라 비교적 높은 신뢰도를 갖는 최소거리 ( $range_{min}$ )와 최대 거리 ( $range_{max}$ )를 설정하였으며 이는 파라미터화하여 신뢰 범위를 설정할 수 있도록 하였다. 수식 (7) ~ (10)과 그림 5. (b)에서 확인할 수 있듯이 깊이 값 ( $depth$ )이 존재하는 범위에 따라 다른 신뢰도를 가진다. 본 논문에서는 0.5m일 때 가장 높은 신뢰도를 부여하였으며, 그보다 가까거나 멀어지면 신뢰도가 점진적으로 낮아지고 4m 이후로는 일정값이 유지되도록 하였다.

$$A = 1 - \frac{1}{range_{max}} \times (range_{max} - range_{min}), \quad (7)$$

$$B = 1 - \frac{1}{range_{min}} \times (range_{min} - depth), \quad (8)$$

$$C = 1 - \frac{1}{range_{max}} \times (depth - range_{min}), \quad (9)$$

$$DistanceFactor = \begin{cases} A, & depth \geq range_{max} \\ B, & depth \leq range_{min} \\ C, & else \end{cases} \quad (10)$$

이렇게 정해진 Factor 변수에 따라 객체 인식을 통해 얻은 로봇의 위치를 안정적으로 얻기 위한 파티클 필터의 파

티클 개수를 조절하게 된다. 이는 객체 인식을 통해 예측된 로봇 자세의 불확실성 ( $u$ )을 기반으로 조절하는 것인데 이때 불확실성 수식은 (11)과 같으며, 앞서 도출한 Edge Factor ( $E.F.$ )와 Distance Factor ( $D.F.$ )를 통해 도출한다. 요소들로 도출해 낸 신뢰도가 낮을 경우 불확실성은 높고 이에 따라 파티클 필터의 파티클 개수를 늘린다. 신뢰도가 높을 경우에는 불확실성은 줄고 이에 따라 파티클 개수는 줄어들며 불필요한 연산이 줄어든다. 이때 파티클의 최대 및 최소 개수는 각각 1000개와 300개로 한정하였다.

$$u = \frac{((1 - E.F.) + (1 - D.F.))}{2}. \quad (11)$$

적응적 샘플링 기반 파티클 필터링을 통해 최종적으로 도출한 로봇의 위치는 MCL의 파티클 집합을 재배치하는 기준이 된다. 즉, 적응적 샘플링 기반 파티클 필터링을 통해 얻은 로봇의 위치를 기준으로 적절한 원형의 Boundary 안에서 MCL의 파티클 집합이 재배치되는 것이다. 이때 이 Boundary는 파라미터화하여 환경에 맞추어 적절히 조절할 수 있도록 설계하였다.

#### IV. 실험 결과

##### 1. 실험 환경 및 로봇 시스템 구성

실험에 사용된 노트북은 8 Cores, 16 Thread, 30GB of RAM의 하드웨어 사양을 가진다. 실험 환경은 우분투 20.04 Noetic이다. 로봇의 시스템 구성은 그림 6과 같다. 객체 학습과 인식을 위해서는 CUDA 11.1과 Object Detection 알고리즘이 사용되었고, 객체 인식을 위한 센서로는 RGB-D 카메라가 사용되었다. 위치추정에 사용된 LiDAR는 2D LiDAR 센서이다. 사용된 두 센서의 프레임은 모두 15Hz이다. 실험을 위해 사용된 환경은 총 3개의 환경이며, 모두 좁고 긴 복도 구간을 포함하고 있다. 사용된 환경의 지도와 로봇의 시작 위치, 진행 방향은 그림 7, 8, 9의 (a)와 같다.

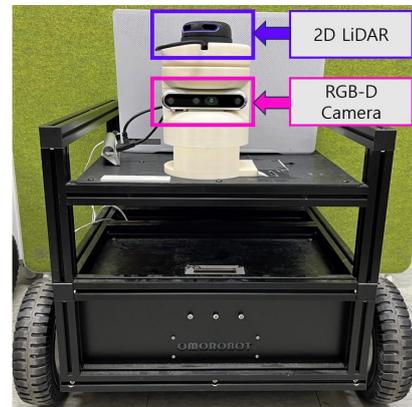


그림. 6. 시스템 구성

Fig. 6. System Configuration

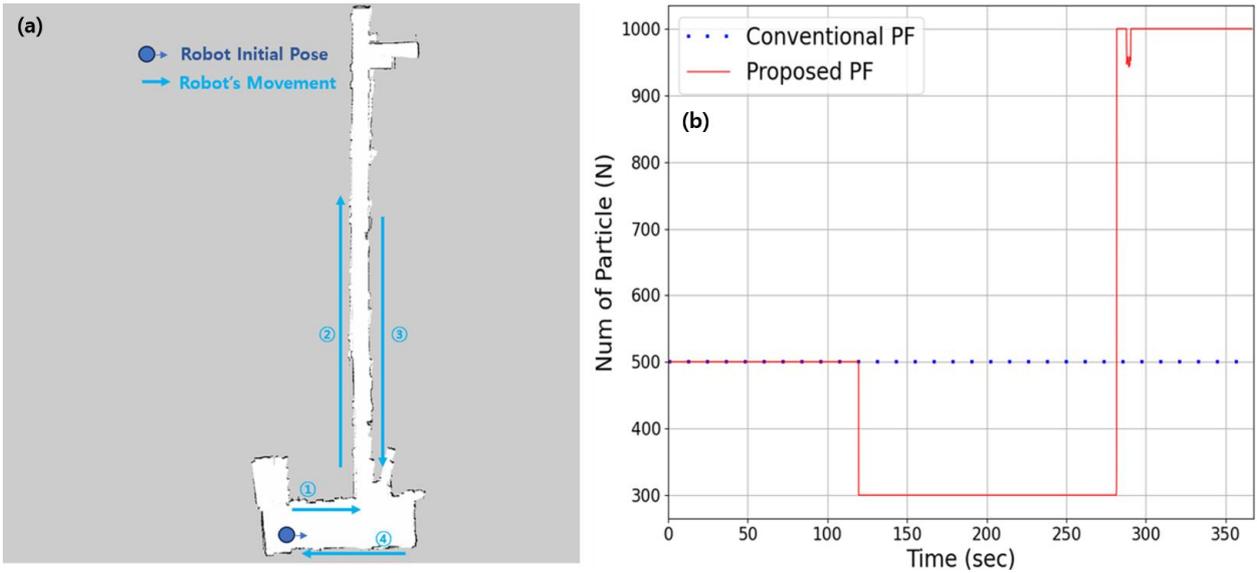


그림. 7. (a). 환경 지도 ① (b). 환경 ①에서의 파티클 개수 비교 결과  
 Fig. 7. (a). Environment Map ① (b). The Comparison Result of Number of Particle in Environment ①

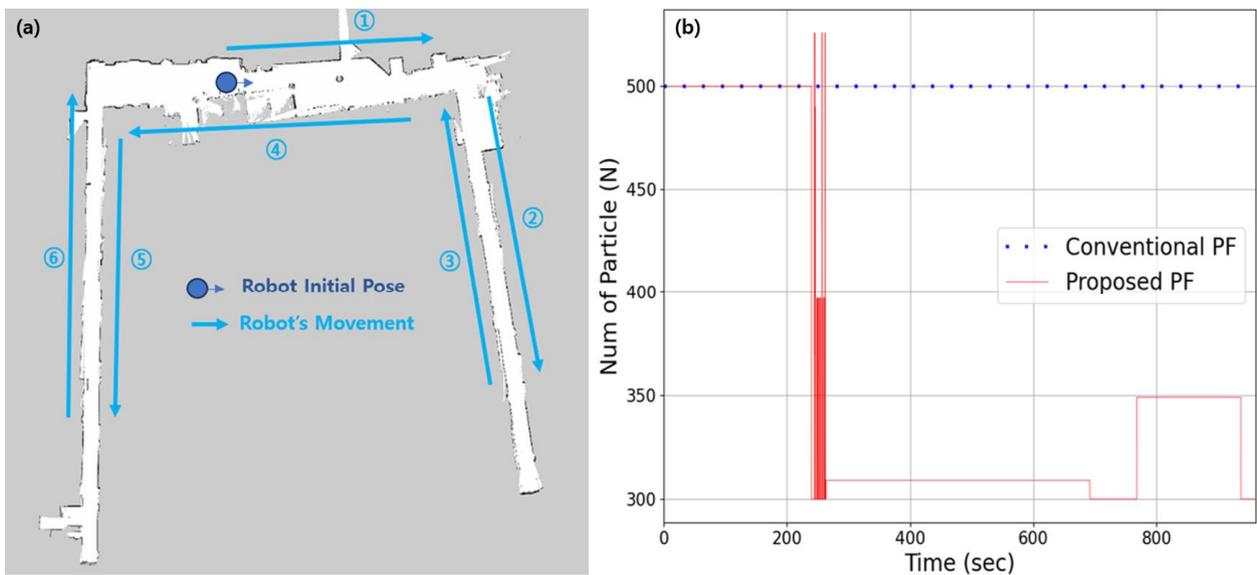


그림. 8. (a). 환경 지도 ② (b). 환경 ②에서의 파티클 개수 비교 결과  
 Fig. 8. (a). Environment Map ② (b). The Comparison Result of Number of Particle in Environment ②

2. 적응적 샘플링 기반 파티클 필터링 결과

앞서 언급한 대로 실험은 총 3가지의 다른 환경에서 진행되었다. 그림 7. (a)에서 표현된 환경은 좁은 복도가 포함된 비교적 작은 환경이고 그림 8. (a)는 좁은 복도가 포함된 넓은 환경이며 그림 9. (a)는 좁은 복도와 난간이 포함된 넓은 환경이다. 각 환경 지칭의 편의성을 위해 순서대로 환경 ①, 환경 ②, 환경 ③으로 명명하기로 한다. 각 세 가지의 환경에서 기존 파티클 필터의 고정적인 파티클 개수와 제안된 파티클 필터의 적응적 파티클 개수를 비교한 결과는 그림 7, 8, 9의 (b) 같다. 그림 7. (b), 8. (b), 9. (b)를 통해 객체 인식을 수행할 때, 카메라의 왜곡 등을 고려하여 파티클의 개수를

적응적으로 조절하였음을 알 수 있고, 파티클의 최대 및 최소 개수에 맞게 적절하게 조절되었음을 확인할 수 있다

환경 ①에서의 파티클 개수를 비교한 결과인 그림 7. (b)를 보면, 파티클 개수의 초기 설정값인 500으로 고정되다가 첫 번째 객체를 인식한 후, 카메라 깊이 데이터를 고려한 Edge Factor와 Distance Factor에 의해 현재 로봇 위치의 불확실성이 결정된다. 첫 번째 객체를 인식한 지점에서 결정된 불확실성이 낮았기 때문에, 파티클의 초기 개수보다 낮은 약 300개의 파티클 개수가 결정되었고, 복도를 빠져나온 후, 두 번째 객체를 인식한 지점에서는 재추정된 불확실성이 높았기 때문에, 이를 고려하여 기존 개수보다 높은 최

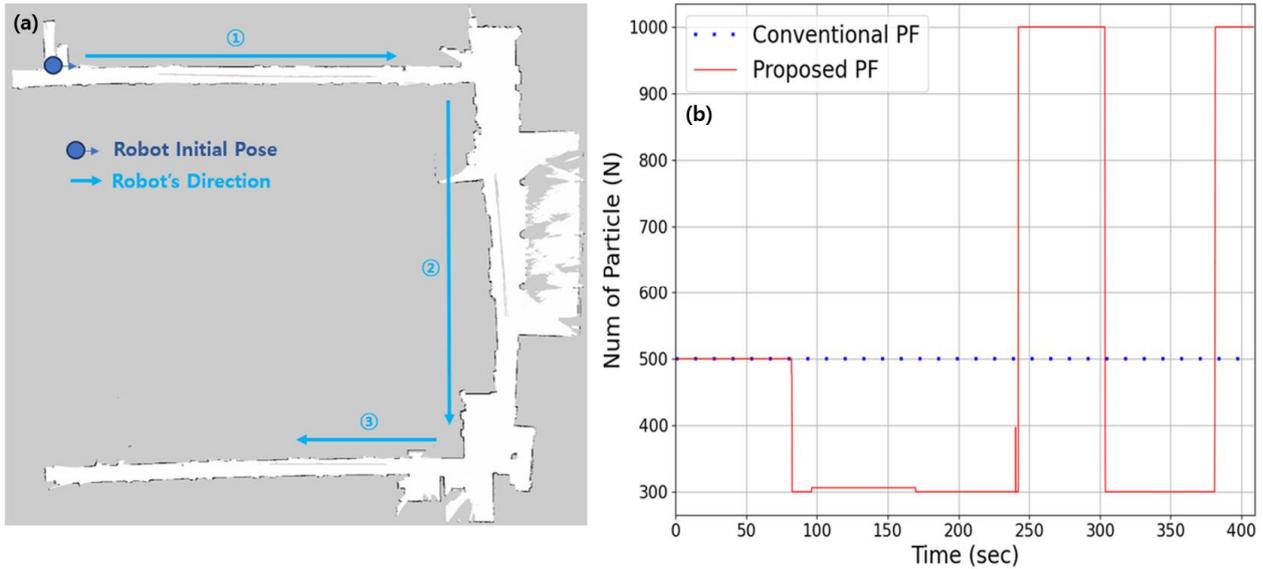


그림. 9. (a). 환경 지도 ③ (b). 환경 ③에서의 파티클 개수 비교 결과  
 Fig. 9. (a). Environment Map ③ (b). The Comparison Result of Number of Particle in Environment ③

표 3. 환경 ①에서의 로봇-객체 상대적 위치추정 오차 비교  
 Table 3. Comparison Results of Robot-Object Relative Position Error in Environment ①

Case ①	Detph	Conventional PF	Proposed
x (m)	0.932	0.924	<b>0.870</b>
y (m)	0.230	0.227	<b>0.128</b>

표 4. 환경 ②에서의 로봇-객체 상대적 위치추정 오차 비교  
 Table 4. Comparison Results of Robot-Object Relative Position Error in Environment ②

Case ②	Detph	Conventional PF	Proposed
x (m)	0.912	0.913	<b>0.905</b>
y (m)	1.292	1.294	<b>1.258</b>

표 5. 환경 ③에서의 로봇-객체 상대적 위치추정 오차 비교  
 Table 5. Comparison Results of Robot-Object Relative Position Error in Environment ③

Case ③	Detph	Conventional PF	Proposed
x (m)	0.646	0.572	<b>0.536</b>
y (m)	0.048	0.039	<b>0.019</b>

대치에 가까운 개수가 적용되어 로봇 위치가 추정되었다. 각 환경 ②, ③에서의 파티클 개수 비교 결과인 그림 8. (b), 9. (b)도 마찬가지로 객체 인식 지점에서의 각 신뢰도와 불확실성을 고려하여 파티클 개수의 최소, 최대치에 맞게 적응적으로 조절된 것을 확인할 수 있다.

추가로 적응적 샘플링 기반 파티클 필터링의 성능을 확인하기 위해, 각 세 가지 환경에 대해 객체 인식을 수행하고 인식 지점에서의 위치추정 오차를 비교한 결과는 표 3, 4, 5와

같다. 단순 Depth 정보 기반 위치추정, Depth 정보에 고정 파티클 개수를 적용한 Conventional 파티클 필터, 마지막으로 파티클의 개수를 적응적으로 조절한 제안된 기법에 대해 위치 오차 결과 비교를 수행하였다. Ground Truth와의 비교 결과 제안된 기법이 세 가지 모든 환경에 대해 가장 낮은 오차를 보였으며, 전체적으로 단순 Depth 기반과 Conventional PF가 비슷한 결과를 보였으나, Conventional PF가 단순 Depth와 비교하였을 때 조금 더 나은 결과를 보였다.

### 3. 로봇 위치추정 결과

환경 ①인 그림 7에서 진행된 실험에서 객체는 긴 복도구간의 중간 정도에 하나, 그리고 비교적 개방되어 있지만 우리가 존재하는 공간에 1개로 총 2개 두었고, 기존 MCL 알고리즘 두 가지 (EMCL2, AMCL)와 제안된 기법으로 로봇 위치추정 실험이 진행되었다.

그림 10은 환경 ①에서 진행된 실험의 위치추정 결과이다. 이때 기존 MCL로 추정된 로봇의 위치, 즉 궤적은 파란색 점선으로 표현하였고 제안된 기법은 빨간색 실선으로 표현하였으며 Ground Truth는 X로 표시하였다. 기존 MCL 알고리즘들은 복도를 진입하면서 점차 위치추정 오차가 누적되었고, 누적된 오차로 인해 복도를 빠져나오면서 위치추정 결과가 크게 틀어진 것을 확인할 수 있다. 그에 반해 적응적 샘플링 기반 파티클 필터링 기법을 적용한 제안된 방법은 복도 진입 구간과 빠져나오는 구간에서 위치추정이 틀어지지 않고 잘 수행되었다.

환경 ②에서의 실험은 총 3개의 객체로 진행되었으며 2개의 객체는 각 양쪽 좁은 복도에 하나씩 있으며, 나머지 1개의 객체는 그림 11의 왼쪽 복도를 빠져나와 비교적 개방된 공간에 위치하고 있다. 환경 ② 또한 기존 MCL 알고리즘들과 제안된 기법 각각의 로봇 위치추정 실험이 진행되었고,

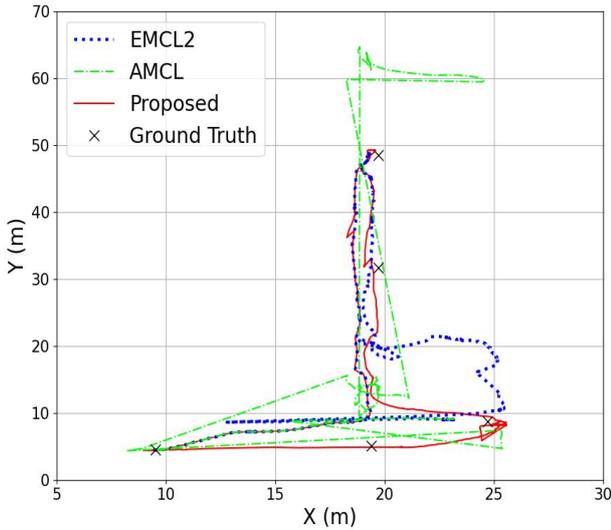


그림. 10. 환경 ①에서의 로봇 위치추정 궤적 결과  
Fig. 10. The result of robot localization in Environment ①

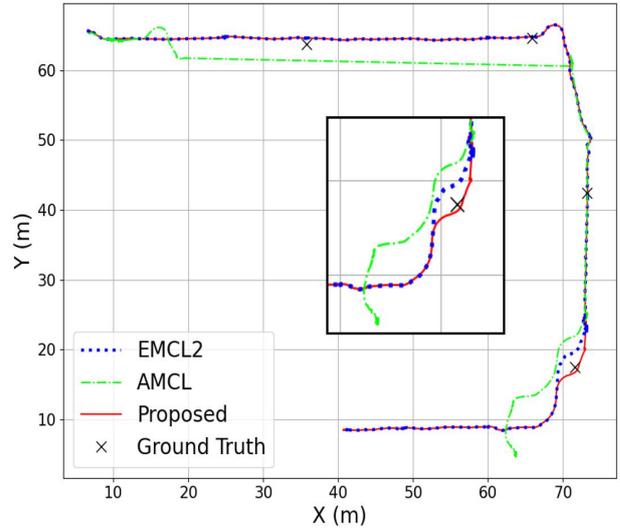


그림. 12. 환경 ③에서의 로봇 위치추정 궤적 결과  
Fig. 12. The result of robot localization in Environment ③

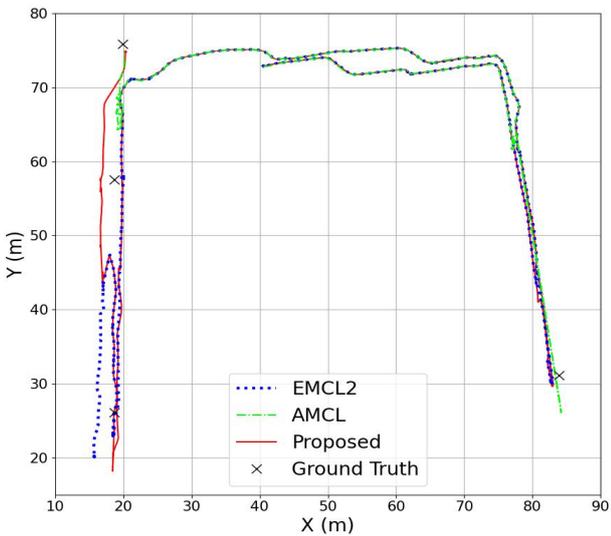


그림. 11. 환경 ②에서의 로봇 위치추정 궤적 결과  
Fig. 11. The result of robot localization in Environment ②

복도에 적재된 물건과 타 환경에 비해 더 좁은 복도 환경임을 고려하여 MCL의 파티클들이 초기화되는 범위는 0.03m로 설정하였다.

그림 11은 환경 ②에서 진행된 실험 결과이다. 오른쪽 복도 구간에서는 EMCL2와 AMCL, 그리고 제안된 기법 모두 비슷한 위치추정 결과를 보였지만, 두 번째 진입 복도인 왼쪽 복도 부분에서 기존 두 가지의 MCL 알고리즘 모두 위치추정 결과가 틀어진 것을 확인할 수 있다. 그림 11에서의 왼쪽 복도 구간 결과를 보면 EMCL2는 두 번째 복도를 진입한 후 빠져나올 때, 현재 진행 방향과는 다르게 반대로 가는 결과를 나타내었다. 또한, AMCL 알고리즘은 아예 복도로 진입하지 못하는 잘못된 위치추정 결과를 나타내었다. 그에 반해 제안된 기법은 두 번째 복도에 잘 진입하고, 빠

져나와 객체를 인식한 후 정확한 위치로 업데이트를 수행하였으며, 전체적으로 안정적인 궤적 결과를 보였다.

마지막으로 환경 ③에서의 실험은 총 5개의 객체로 진행되었으며 3개의 객체는 좁은 복도에 있고, 4번째 객체는 난간, 그리고 마지막 객체는 난간을 지난 뒤 좁은 복도에 위치하고 있다. 그림 12는 환경 ③에서의 각 MCL 알고리즘과 제안된 기법의 위치추정 궤적 결과를 나타낸다. 기존 MCL과 제안된 기법이 다른 결과를 보였던 객체 인식 지점을 확대하여 그래프에 함께 표시하였다. MCL은 개방된 곳에 진입할 무렵 위치추정에 실패했음을 확인할 수 있다. 특히 AMCL 알고리즘은 두 가지의 복도 구간에서 모두 낮은 위치추정 정확도를 보였다. 그에 반해 제안된 기법은 객체를 인식한 후, 위치 좌표가 업데이트되어 더 정확한 위치로 이동한 것을 확인할 수 있으며, 그 이후에도 객체를 인식하여 안정적으로 로봇 위치추정을 수행하였다.

4. 로봇 위치추정 결과에 대한 정량적 비교 및 분석

표 6은 각 그림 7, 8, 9의 실험 환경에서 사전에 측정된 Ground Truth를 기준으로 Odometry, EMCL2, AMCL, 그리고 제안된 기법의 RMSE (Root Mean Square Error)를 비교한 정량적 비교 결과이다. 이때 Case ①, Case ②, Case ③은 순서대로 그림 7, 8, 9의 실험 환경을 의미한다. RMSE는 예측된 값과 실제 값의 차이를 측정하는 데 사용되는 통

표 6. 위치 오차에 대한 RMSE 결과 비교

Table 6. Position Error Comparison of RMSE Results

	Odometry	EMCL2	AMCL	Proposed
Case ① (m)	0.712	7.284	9.767	<b>0.629</b>
Case ② (m)	10.543	21.701	17.938	<b>1.978</b>
Case ③ (m)	2.702	0.966	20.824	<b>0.379</b>

계적 지표이다. RMSE는 MSE에 제곱근을 취하여 원래 데이터의 단위를 유지하며, 특히 큰 오차에 더 많은 가중치를 두어 오차의 실제 편차를 강조한다. 각 알고리즘의 RMSE가 낮을수록 예측된 위치가 실제 위치에 더 가깝다는 것을 의미하며, 각 환경에서의 실제 값 (Ground Truth)과 예측된 값 (Odometry, EMCL2, AMCL, Proposed)을 사용하여 RMSE를 구해주었다. 결과적으로 세 가지 환경에서 모두 가장 낮은 RMSE 값을 가진 제안된 기법이 높은 정확도를 가짐을 보여준다.

Case ①에서의 위치 오차에 대한 RMSE 결과 값은 제안된 기법이 0.629 (m)의 가장 낮은 결과로 높은 정확도를 보인 것을 확인할 수 있으며, 두 번째로는 Odometry가 0.712 (m)의 결과를 나타냈다. 복도 구간 때문에 발생하는 랭크 결핍 문제로 인해 EMCL2 기법은 7.284 (m), 그리고 AMCL은 9.767 (m)의 큰 오차가 발생하였음을 알 수 있다. Case ②에서 가장 낮은 오차를 보인 알고리즘은 역시 제안된 기법이며, 두 번째 긴 복도 구간으로 인해 오차가 지속적으로 누적된 EMCL2 기법이 21.702 (m)로 가장 높은 위치추정 오차 값을 나타내었다. Case ③에서는 AMCL이 20.824 (m)의 제일 큰 오차를 보였으며, 전체적으로 기존 EMCL2 기법과 제안된 기법의 위치추정 결과가 비슷했으나, 제안된 기법이 그림 9. (a)에서 객체를 인식한 후, 위치 좌표가 더 정확하게 업데이트되었기 때문에, 오차 값이 가장 낮게 나온 것을 확인할 수 있다. 결과적으로 각 환경에서 모두 제안된 기법이 오차가 제일 낮았으며, 세 가지 환경에서의 RMSE 오차 값을 단순 평균 내었을 때, Odometry가 4.652 (m), EMCL2는 9.984 (m), 그리고 AMCL이 16.18 (m)로 높은 오차를 보였고, 제안된 기법이 0.9953 (m)로 제일 낮은 오차를 나타내었다.

## V. 결론

본 연구는 실시간 로봇 시스템에서 LiDAR 기반의 위치 추정 시 스캔 매칭의 Rank Deficiency 문제를 해결하고자 RGB-D 카메라를 이용하여 로봇의 위치를 정확하게 추정하기 위한 적응적 샘플링 기반 파티클 필터링 기법을 제안하였다. 이때 카메라 센서 기반 객체 및 로봇의 위치추정 또한 카메라 센서의 노이즈, 왜곡 등으로 인한 오차가 있었다. 이를 해결하기 위해 로봇 위치의 불확실성을 수치화하였고, 카메라 센서를 통한 객체 인식으로 위치추정을 함에 있어서 불확실성에 따라 파티클의 개수를 조절하였다. 따라서 불확실성이 높을수록 더 많은 파티클이 사용되었고 불확실성이 낮을수록 더 적은 파티클이 사용되었다.

제안된 기법의 성능을 검증하기 위해 3가지 복도 환경에서 실제 실험이 수행되었고 로봇 위치추정 결과의 오차 평균 및 표준편차를 감소시킴으로써 기존 방법 대비 성능이 향상되었음을 검증하였다.

## References

- [1] Y. Li, J. L. Guzman, "Lidar for Autonomous Driving: The Principles, Challenges, and Trends for Automotive Lidar and Perception Systems," *IEEE Signal Processing Magazine*, Vol. 37, No. 4, pp. 50-61, 2020.
- [2] M. Wu, J. Y. Sun, "Simultaneous Localization, Mapping and Detection of Moving Objects with Mobile Robot in Dynamic Environments," *2nd International Conference on Computer Engineering and Technology*, Vol. 1, pp. VI-696, 2010.
- [3] W. Tan, H. Liu, Z. Dong, G. Zhang, H. Bao, "Robust Monocular SLAM in Dynamic Environments," *IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, 2013.
- [4] G. Ge, Y. Zhang, W. Wang, Q. Wang, "Medical Mobile Robot Localization in Hospital Corridor Environment Using Laser SLAM and Text Features," *Journal of Imaging Science & Technology*, Vol. 66, No. 4, pp. 1-14, 2022.
- [5] R. P. Padhy, S. Ahmad, S. Verma, S. Bakshi, P. K. Sa, "Localization of Unmanned Aerial Vehicles in Corridor Environments using Deep Learning," *25th International Conference on Pattern Recognition (ICPR)*, pp. 9423-9428, 2020.
- [6] G. Ge, Y. Zhang, W. Wang, L. Hu, Y. Wang, Q. Jiang, "Visual-feature-assisted Mobile Robot Localization in a Long Corridor Environment," *Frontiers of Information Technology & Electronic Engineering* Vol. 24, pp. 876 - 889, 2023.
- [7] M. Kim, D. Han, J. Rhee, "Multiview Variational Deep Learning With Application to Practical Indoor Localization," *IEEE Internet of Things Journal*, Vol. 8, No. 15, pp. 12375-12383, 2021.
- [8] L. Batistic, M. Tomic, "Overview of Indoor Positioning System Technologies," *International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pp. 0473-0478, 2018.
- [9] S. M. Kumar, S. Sinha, "Improved RSSI Based 3D Localization for Indoor Wireless Sensor Network," *4th International Conference on Inventive Research in Computing Applications (ICIRCA)*, pp. 478-483, 2022.
- [10] S. A. Samadh, Q. Liu, X. Liu, N. Ghourchian, M. Allegue, "Indoor Localization Based on Channel State Information," *IEEE Topical Conference on Wireless Sensors and Sensor Networks (WiSNet)*, pp. 1-4, 2019.
- [11] N. H. H. Pham, M. A. Nguyen, C. Sun1, "Indoor Positioning System using UWB and Kalman filter to increase the accuracy of the Localization System," *IEEE International Conference on Consumer Electronics*, pp. 339-340, 2022.
- [12] G. Grisetti, C. Stachniss, W. Burgard, "Improving Grid-based SLAM with Rao-Blackwellized Particle Filters by Adaptive Proposals and Selective Resampling," *Proceedings of the IEEE International Conference on Robotics and Automation*, pp. 2432-2437, 2005.
- [13] J. W. Kim, H. C. Lee, "GPU-based Acceleration of Particle

- Filters for Real-Time Target Localization," KSAS 2021 Fall Conference, pp. 1439-1440, Nov. 2021 (in Korean).
- [14] J. Kim, S. Nam, G. Oh, S. Kim, S. Lee, H. C. Lee, "Implementation of a Mobile Multi-Target Search System with 3D SLAM and Object Localization in Indoor Environments," 2021 21st International Conference on Control, Automation and Systems (ICCAS), Jeju, Korea, pp. 2083-2085, Oct. 2021.
- [15] I. S. Jang, H. W. Kim, H. C. Lee, "Object-Centered Spectral Matching for Efficient Environmental Information Fusion in Multiple Small Robot Systems," Korean Institute of Information Technology, Vol. 21, No. 8, pp. 27-38, 2023 (in Korean).
- [16] S. H. Kim, K. S. Oh, "Development of a Path Tracking Control Algorithm of Autonomous Mobility Using Camera-based Multi-particle Filtering and Weighted Cost Function," The Korean Society of Automotive Engineers (KSAE), Vol. 32, No. 1, pp. 15-26 (in Korean).
- [17] D. Han, S. Bae, S. Park, S. Jin, "Obstacle Tracking Algorithm in Port Environment Using Multi-Lidar Sensor," 2021 Korea Automotive Engineering Society Spring Conference, pp. 497-502, 2021 (in Korean).
- [18] A. Mukhtar L. Xia, "Target Tracking Using Color Based Particle Filter," 2014 5th International Conference on Intelligent and Advanced Systems (ICIAS), Kuala Lumpur, Malaysia, pp. 1-6, 2014.
- [19] P. Tian, "A Particle Filter Object Tracking Based on Feature and Location Fusion," 2015 6th IEEE International Conference on Software Engineering and Service Science (ICSESS), Beijing, China, pp. 762-765, 2015.
- [20] H. S. Park, C. J. Ho, "Signal Compensation of LiDAR Sensors and Noise Filtering," Journal of Sensor Science and Technology (JSSST), Vol. 28, No. 5, Telecommunication, pp. 334-339, 2019 (in Korean).
- [21] S. Baek, A. Kim, S. Ha, T. Kim J. W. Kim, "Development of an Object Tracking System using Sensor Fusion of a Camera and LiDAR," Journal of Korean Institute of Intelligent Systems, Vol. 32, No. 6, pp. 500 - 506, 2022 (in Korean).
- [22] S. W. Jeon, S. Jeong. "Localization and Control of an Outdoor Mobile Robot Based on an Estimator with Sensor Fusion," IEMEK Journal of Embedded Systems and Applications, Vol. 4. No. 2, pp. 69-78. 2009.
- [23] R. Ueda, T. Arai, K. Sakamoto, T. Kiduchi, S.Kamiya, "Expansion Resetting for Recovery from Fatal Error in Monte Carlo Localization - Comparison with Sensor Resetting Methods," 22004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)(IEEE Cat. No. 04CH37566). Vol. 3, pp. 2481-2486, 2004.
- [24] D. Choi, M. Y. Kim, and B. H. Kim, "Dynamic 3D Worker Pose Registration for Safety Monitoring in Manufacturing Environment based on Multi-domain Vision System," IEMEK Journal of Embedded Systems and Applications, Vol. 18, No. 6, pp. 303 - 310, Dec. 2023.
- [25] G. D. Park, J. H. Kim, J. K. Choi, "Estimation of Road Surface Condition and Tilt Angle to Improve the Safety of Mobility Aids for the Elderly," IEMEK Journal of Embedded Systems and Applications, Vol. 17, No. 3, pp. 149 - 155, 2022.

### Suhyeon Kang (강수현)



2023 Department of Control and Robot Engineering, School of Electronic Engineering, Kumoh National Institute of Technology (B.S.)

2023~Department of IT Convergence Engineering, School of Electronic Engineering, Kumoh National Institute of Technology (M.S.)

Field of Interests: Robot localization, Autonomous navigation, SLAM, Sensor fusion, Computer vision

Email: 20236101@kumoh.ac.kr

### Yujin Kwon (권유진)

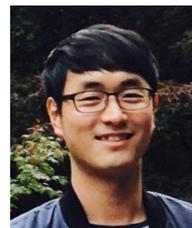


2020~Department of Electronics and IT Convergence, School of Electronic Engineering, Kumoh National Institute of Technology (B.S.)

Field of Interests: Robot localization, Autonomous navigation

Email: yuwls@kumoh.ac.kr

### Heoncheol Lee (이현철)



2006 Electronic-Electrical Engineering and Computer Sciences from Kyungpook National University (B.S.)

2008 Electrical Engineering and Computer Sciences from Seoul National University (M.S.)

2013 Electrical Engineering and Computer Sciences from Seoul National University (Ph.D.)

2019~Department of IT Convergence Engineering, School of Electronic Engineering, Kumoh National Institute of Technology (Associate Professor)

Career:

2011 Researcher, ASRI, Seoul National University

2013 Senior Researcher, Agency for Defense Development

2019 Technical Adviser, LG Electronics

Field of Interests: SLAM, Path Planning, GPU/FPGA-based Algorithm Acceleration, Deep Learning

Email: hclee@kumoh.ac.kr